

## 基于残差密集网络的频谱感知方法

盖建新, 薛宪峰, 南瑞祥, 吴静谊

(哈尔滨理工大学测控技术与仪器黑龙江省高校重点实验室, 黑龙江 哈尔滨 150080)

**摘 要:** 针对传统卷积神经网络 (CNN) 频谱感知方法没有充分利用特征图信息并且提取特征图的能力受限于浅层的网络结构等问题, 通过在传统 CNN 频谱感知方法中添加密集连接, 实现特征图信息重利用, 同时在密集单元的两端加入捷径连接, 实现更深层的网络训练, 进而提出一种基于残差密集网络 (ResDenNet) 的频谱感知方法。该方法将频谱感知问题映射为图像二分类问题, 首先对接收信号分割成矩阵并归一化灰度处理, 得到的灰度图像作为网络的输入, 然后通过密集学习和残差学习训练网络, 最后将在线数据输入 ResDenNet 中, 完成基于图像分类的频谱感知。数值实验表明, 所提方法优于传统频谱感知方法, 在信噪比低至  $-19$  dB 时, 所提方法检测概率仍高达 0.96, 虚警概率低至 0.1, 同时具有更好的泛化能力。

**关键词:** 频谱感知; 残差密集网络; 密集连接; 捷径连接

**中图分类号:** TN911

**文献标识码:** A

**DOI:** 10.11959/j.issn.1000-436x.2021220

## Spectrum sensing method based on residual dense network

GAI Jianxin, XUE Xianfeng, NAN Ruixiang, WU Jingyi

The Higher Educational Key Laboratory for Measuring & Control Technology and Instrumentations of Heilongjiang Province,  
Harbin University of Science and Technology, Harbin 150080, China

**Abstract:** Aiming at the problem that the traditional spectrum sensing method based on convolutional neural network (CNN) did not make full use of image feature and the ability of extracting the image feature was limited by the shallow network structure, a spectrum sensing method based on the residual dense network (ResDenNet) was proposed. By adding dense connections in the traditional neural network, the information reuse of the image feature was achieved. Meanwhile, shortcut connections were employed at both ends of the dense unit to implement deeper network training. The spectrum sensing problem was transformed into the image binary classification problem. Firstly, the received signals were integrated into a matrix, which was normalized and transformed by gray level. The obtained gray level images were used as the input of the network. Then, the network was trained through dense learning and residual learning. Finally, the online data was input into the ResDenNet and spectrum sensing was implemented based on image classification. The numerical experiments show that the proposed method is superior to the traditional ones in terms of performance. When the SNR is as low as  $-19$  dB, the detection probability of the proposed method is still high up to 0.96 with a low false alarm probability of 0.1, while a better generalization ability is displayed.

**Keywords:** spectrum sensing, ResDenNet, dense connection, shortcut connection

收稿日期: 2021-08-16; 修回日期: 2021-11-04

基金项目: 国家自然科学基金资助项目 (No.61501150); 黑龙江省自然科学基金资助项目 (No.QC2014C074); 黑龙江省省属本科高校基本科研业务费基金资助项目 (No.2018-KYYWF-1656)

**Foundation Items:** The National Natural Science Foundation of China (No.61501150), The Natural Science Foundation of Heilongjiang Province (No.QC2014C074), The Fundamental Research Funds for the Universities in Heilongjiang Province (No.2018-KYYWF-1656)

## 1 引言

频谱感知是认知无线电 (CR, cognitive radio) 的核心技术之一。传统频谱感知方法主要包括能量检测法<sup>[1-3]</sup>、循环平稳特征检测法<sup>[4-5]</sup>、匹配滤波检测法<sup>[6]</sup>、特征值检测法<sup>[7]</sup>等。这些方法主要面向高斯白噪声 (WGN, white Gaussian noise) 干扰下的频谱感知问题, 频谱感知前需先计算检测门限。在实际无线电环境中, 噪声不一定服从高斯分布, 计算出的检测门限也是近似值, 检测门限的准确与否将直接影响频谱感知的检测性能。

为克服传统频谱感知方法不易确定检测门限的问题, 学者们提出了基于机器学习的频谱感知方法。此类方法不需要计算检测门限, 利用训练分类器就可完成信号识别。Awe 等<sup>[8]</sup>、Bao 等<sup>[9]</sup>和陈思吉等<sup>[10]</sup>提出了基于支持向量机 (SVM, support vector machine) 的频谱感知方法, SVM 将采样到的能量信号作为训练集与测试集, 能够对信号与噪声进行分类识别。但是该方法需求解特征参数并且存在感知时间长的缺点。Tang 等<sup>[11]</sup>和 Vyas 等<sup>[12]</sup>分别提出基于人工神经网络 (ANN, artificial neural network) 的频谱感知方法, ANN 将信号能量与周期平稳特征作为输入, 用训练好的 ANN 实现频谱感知。与 SVM 相比, ANN 通过调整权值、偏置, 可提高频谱感知的准确度。ANN 采用反向传播算法, ANN 层数越多越容易出现梯度消失问题。卷积神经网络 (CNN, convolutional neural network) 利用卷积层、池化层、全连接层等多层网络结构, 可克服二维图像特征提取困难, 便于处理图像识别与分类任务<sup>[13]</sup>。高红民等<sup>[13]</sup>、Yu 等<sup>[14]</sup>、Maffei 等<sup>[15]</sup>和 Chen 等<sup>[16]</sup>分别将 CNN 应用到高光谱图像识别领域, 通过提取图像特征, 训练高光谱分类网络, 最后将高光谱图像输入 CNN 中并取得良好的分类准确率。Liu 等<sup>[17]</sup>、Lee 等<sup>[18]</sup>和张孟伯等<sup>[19]</sup>将 CNN 用于解决频谱感知问题, CNN 的数据集由接收信号的灰度图像组成, 此类方法训练 CNN 提取图像的特征, 将在线数据输入 CNN 中进行频谱感知。CNN 避免了计算检测门限, 省去了求解特征参数; 但其对特征图信息利用率低且提取的特征信息有限, 频谱感知的准确率有待提高。

捷径连接最早在 Hopfield Network<sup>[20]</sup>中提

出, 通过在任意 2 个神经元之间添加捷径连接, 使梯度能够传递到其他神经元, 加速信息传递。多层感知机也利用捷径连接缓解梯度消失问题, 训练深层网络<sup>[21]</sup>。密集连接的思想早期体现在神经网络结构中, 前一层的所有神经元直接和下一层的神经元相连, 形成一个类似于扇形的密集结构<sup>[22]</sup>。下一层的神经元充分利用前一层的所有神经元的消息, 神经元之间的密集连接有利于神经网络的训练。Wilamowski 等<sup>[23]</sup>在全连接层使用密集连接, 通过全连接层中两两相连的神经元进行信息传递, 提高了网络分类的准确率。在传统 CNN 频谱感知方法中加入捷径连接, 有望训练更深的网络, CNN 提取特征的能力随着网络层数的增多而增强。在传统 CNN 频谱感知方法中加入密集连接, 有望实现任意 2 个卷积层特征提取信息重利用, 有助于提升图像分类和识别的准确率, 有望克服传统 CNN 频谱感知方法未能有效利用特征图信息并且提取图像特征能力薄弱等问题。

本文为充分利用传统 CNN 频谱感知方法的特征图信息, 并训练深层网络来提高特征图信息提取能力, 在传统 CNN 频谱感知方法中加入捷径连接和密集连接, 提出一种残差密集网络 (ResDenNet, residual dense network) 频谱感知方法。该方法首先将接收信号分割成矩阵, 对矩阵进行归一化处理并转为灰度图像作为 ResDenNet 的输入; 然后使用 ResDenNet 中的基本密集单元提取灰度图像的特征, 进行局部特征融合, 在密集单元两端引入捷径连接, 提取任意的密集单元特征, 进行特征融合; ResDenNet 训练完成后, 将在线数据输入 ResDenNet 中, 完成频谱感知。

## 2 感知模型

在 CR 网络中, 非授权用户检测有无授权用户信号可对应为二元假设检验问题

$$\left. \begin{aligned} H_0: \mathbf{x}(n) &= \mathbf{u}(n) \\ H_1: \mathbf{x}(n) &= \mathbf{s}(n) + \mathbf{u}(n) \end{aligned} \right\} \quad (1)$$

其中,  $H_0$  表示频谱信道空闲, 即不存在授权用户信号;  $H_1$  表示频谱信道占用, 即存在授权用户信号。 $n$  表示采样点数,  $\mathbf{x}(n)$  表示接收信号,  $\mathbf{s}(n)$  表示受到瑞利信道衰落的授权用户的发射信号,  $\mathbf{u}(n)$  表示均值为 0 且方差为  $\sigma^2$  的高斯分布噪声。从分类的角

度可将  $H_0$  和  $H_1$  表示为二分类问题:  $H_0$  只有噪声,  $H_1$  有授权用户的发射信号和噪声。本文使用检测概率  $P_d$  和虚警概率  $P_{fa}$  这 2 个频谱感知性能指标来评价算法性能。其中,  $P_d$  是指授权用户存在且被成功检测的概率,  $P_{fa}$  是指授权用户不存在却被错误检测为存在的概率, 可分别表示为

$$\begin{aligned} P_d &= P\{H_1|H_1\} \\ P_{fa} &= P\{H_1|H_0\} \end{aligned} \quad (2)$$

设非授权用户接收的  $n$  个采样点的信号向量为

$$\mathbf{x}(n)=[x(1),x(2),x(3),\dots,x(n)] \quad (3)$$

信号向量经过  $I$ 、 $Q$  解调后分割成 2 个  $M$  行、 $n/M$  列的信号矩阵。

信号矩阵存在 2 种情况, 一种情况是存在授权用户的发射信号与噪声, 另一种情况是仅存在噪声。有无发射信号的区别在于采样矩阵的整体分布不同。

### 3 基于 ResDenNet 的频谱感知方法描述

传统 CNN 频谱感知方法<sup>[17]</sup>采用 LeNet-5 网络结构, 将接收信号  $\mathbf{X}$  的矩阵灰度图作为 CNN 的输入层, 通过卷积 (Conv, convolution)、池化 (Pooling)、激活函数 ReLU 和全连接 (FC, full connection) 整合提取特征, 输出层利用 Softmax, 输出结果为  $H_0$ 、 $H_1$ 。传统 CNN 频谱感知方法存在两方面的不足。一方面, 传统 CNN 频谱感知方法的当前层的特征信息经过 Conv 或 Pooling 操作后, 不会参与之后的计算, 导致对特征信息的浪费。另一方面, 传统 CNN 频谱感知方法结构简单, 不能提取更深层的灰度图像特征。若直接增加过多的层数, 会发生梯度消失, 梯度一旦消失, CNN 无法更新权值信息, 导致频谱感知性能下降。

针对上述问题, 本文在传统 CNN 频谱感知方法中加入密集连接, 使基本密集单元中的 Conv 相互传递信息, 将特征图信息利用最大化。同时, 在

传统 CNN 频谱感知方法中添加捷径连接可解决梯度消失问题, 使输入层恒等映射更深层的网络结构。CNN 深度的增加提升了图像分类和识别的准确率。本文在传统 CNN 频谱感知方法中结合上述思想, 提出基于 ResDenNet 的频谱感知方法。该方法首先将接收信号的观测向量分割成矩阵, 将矩阵进行归一化灰度处理作为 ResDenNet 频谱感知模型的输入, 使用离线数据训练 ResDenNet, 将在线数据输入 ResDenNet 中, 进行频谱感知。频谱感知模型如图 1 所示。




图 1 频谱感知模型

#### 3.1 数据预处理

为了仿真实际情况, 本文对发射机和接收机分别进行仿真, 进而生成训练集和测试集。需要指出的是, 对于实际频谱感知系统来说, 只需要接收机部分, 不需要对发射机信号进行上述处理。QPSK 系统发射机与接收机仿真原理如图 2 所示, 发射信号通过串并转换、瑞利衰落信道、加性白高斯噪声 (AWGN, additive white Gaussian noise) 加噪, 得到接收信号。加入 WGN 的发射信号或 WGN 通过正交采样、低通滤波和抽样判决, 得到  $I$ 、 $Q$  两路信号, 然后共同组成频谱感知模型的原始数据, 即

$$\mathbf{X}(n)=\mathbf{I}(n)+j\mathbf{Q}(n) \quad (4)$$

其中,  $\mathbf{I}(n)$ 、 $\mathbf{Q}(n)$  分别代表非授权用户对接收到的  $I$ 、 $Q$  两路信号。对  $I$ 、 $Q$  两路信号的  $n$  个采样点 ( $n$  为  $M$  的整数倍) 等距分割可得到  $M$  行  $n/M$  列的矩阵  $\mathbf{X}_I$  与  $\mathbf{X}_Q$ , 其表达式分别为




图 2 QPSK 系统发射机与接收机仿真原理

$$X_I = \begin{bmatrix} I(1) & I(2) & \cdots & I(\frac{n}{M}) \\ I(\frac{n}{M} + 1) & I(\frac{n}{M} + 2) & \cdots & I(\frac{2n}{M}) \\ \vdots & \vdots & \vdots & \vdots \\ I(\frac{(M-1)n}{M} + 1) & I(\frac{(M-1)n}{M} + 2) & \cdots & I(n) \end{bmatrix}_{M \times \frac{n}{M}} \quad (5)$$

$$X_Q = \begin{bmatrix} Q(1) & Q(2) & \cdots & Q(\frac{n}{M}) \\ Q(\frac{n}{M} + 1) & Q(\frac{n}{M} + 2) & \cdots & Q(\frac{2n}{M}) \\ \vdots & \vdots & \vdots & \vdots \\ Q(\frac{(M-1)n}{M} + 1) & Q(\frac{(M-1)n}{M} + 2) & \cdots & Q(n) \end{bmatrix}_{M \times \frac{n}{M}} \quad (6)$$

对  $X_I$  和  $X_Q$  进行归一化灰度处理, 用灰度值表征矩阵归一化后数值的大小。以矩阵  $X_I$  为例, 归一化灰度处理步骤如下。首先, 计算最大值和最小值的差值的倒数  $rec$  如下

$$rec = \frac{1}{\max(X_I) - \min(X_I)} \quad (7)$$

其次, 设  $x_{m,n}$  为  $X_I$  中第  $m$  行第  $n$  列的数值, 归一化后的数值  $nor(x_{m,n})$  可表示为

$$nor(x_{m,n}) = (x_{m,n} - \min(X_I))rec \quad (8)$$

将归一化灰度处理后的  $X_I$  与  $X_Q$  作为 ResDenNet 频谱感知模型的输入。

### 3.2 捷径连接和密集连接

本文图 3~图 7 中, 实线箭头表示任意 2 个卷积层结构的连接, 虚线箭头表示多个卷积层结构的省略连接。

传统 CNN 频谱感知方法的结构如图 3 所示, 第  $l$  层的输入  $x_l$  映射为第  $L$  层的输出  $H(x_L)$ 。传统 CNN 频谱感知方法若堆叠过多的网络层数, 当反向传播更新权重、偏置以及损失函数时, 会导致梯度消失。其原因是, 反向传播采用链式求导方法更新权值, 对权值进行一系列连乘求偏导, 使网络浅层部分的梯度接近于 0, 影响浅层部分的权值得不到更新, 导致频谱感知模型性能下降。




图 3 传统 CNN 频谱感知方法的结构

在传统 CNN 频谱感知方法中加入捷径连接可以改变梯度的流向, 捷径连接通过跳过一个或多个 Conv 实现输出与输入特征图之间的残差映射, 为基本残差块 (BRB, basic residual block), 其结构如图 4 所示,  $F(\cdot)$  表示残差特征映射图,  $x_l$  的梯度通过捷径连接直接传递到  $H(x_S)$ , 特征映射图  $H(x_S)$  可表示为

$$H(x_S) = F(x_S) + x_l \quad (9)$$




图 4 BRB 的结构

残差学习不需要每个输入层  $x_l$  都直接映射一个最优特征映射图  $H(x_S)$ , 而是利用捷径连接实现残差映射  $F(x_S) = H(x_S) - x_l$ , 因此原最优特征映射图  $H(x_S)$  就变成了  $F(x_S) + x_l$ 。BRB 利用捷径连接可使  $x_l$  的梯度信息流向  $S$  层, 避免了发生梯度消失问题, 可利用深层网络强大的特征提取能力进行频谱感知。

BRB 并没有多次利用每个 Conv 输出的信息, 为加强 BRB 的特征提取能力, 本文通过密集连接, 改进 Conv 之间的信息流动, 使任意不同的 Conv 实现特征信息重复利用, 提高网络的特征提取能力。基本密集块 (BDB, basic dense block) 结构如图 5 所示,  $x_l$  可以直接获取  $x_0, x_1, \dots, x_{l-1}$  经过 Conv 操作后的特征图信息,  $x_l$  可表示为

$$x_l = H_l([x_0, x_1, \dots, x_{l-1}]) \quad (10)$$

其中,  $[\cdot]$  表示不同特征图中的密集连接。密集单元内部采用密集连接方式, 将不同 Conv 输出的特征映射图连接起来, 实现了特征图信息连续传递。




图 5 BDB 的结构

### 3.3 残差密集网络

ResDenNet 以残差密集块 (RDB, residual dense block) 为基础, RDB 由多个 Conv 和 ReLU 构成, 起到特征提取的作用, 每个 RDB 中的输出都会与

下一个 RDB 的每个 Conv 的输出建立捷径连接, 实现特征图信息连续传递。第  $d$  个 RDB 结构如图 6 所示。第  $d$  个 RDB 的输入与输出分别为  $F_{d-1}$  和  $F_d$ , RDB 中第  $l$  个 Conv 的输出为

$$F_{d,l} = H_l([F_{d-1}, F_{d,1}, \dots, F_{d,l-1}]) \quad (11)$$

其中,  $H_l(\cdot)$  表示含有批处理归一化 (BN, batch normalization)、ReLU、Conv 等操作的复合函数。




图 6 第  $d$  个 RDB 结构

在 RDB 的输入与输出之间引入捷径连接, 实现局部残差学习。RDB 最后的输出  $F_d$  可表示为

$$F_d = F_{d-1} + F_{d,l} \quad (12)$$

通过将 RDB 的输入和输出相加实现局部残差学习, 进一步提高 RDB 的特征提取能力, 有助于提高频谱感知能力。

RDB 将密集连接和捷径连接的优势结合起来, 实现特征信息连续传递和局部残差学习, 可有效缓解梯度消失, 实现更深的网络, 有望提取频谱信号的深层特征, 克服传统 CNN 频谱感知方法特征提取能力受限的问题。

本文提出的深层 ResDenNet 频谱感知模型由输入层、浅层特征提取 Conv、多个 RDB 级联、FC 和分类标签组成。ResDenNet 频谱感知模型如图 7 所示, 本文将含有接收信号的灰度图像经过浅层卷积层特征提取  $F_0$  作为 RDB 的输入,  $F_0$  表示为

$$F_0 = H(Wx_i) \quad (13)$$

其中,  $x_i$  表示输入的第  $i$  张灰度图像,  $W$  表示  $x_i$  浅层提取的权值,  $H(\cdot)$  表示当前卷积层的非线性操作函数。




图 7 ResDenNet 频谱感知模型

本文在 RDB 内引入了捷径连接, 每个 RDB 的输入都与前面所有 RDB 的输出相连, 形成残差自适应学习, 实现浅层特征与深层特征自适应结合, 充分利用特征图信息并且优化了网络模型。RDB 通

过 Conv、ReLU 等操作, 提取灰度图像的密集特征,  $F_d$  的计算式为

$$F_d = H_{\text{RDB},d}(F_{d-1}) = H_{\text{RDB},d}(H_{\text{RDB},d-1}(\dots H_{\text{RDB},1}(F_0)\dots)) \quad d \geq 1 \quad (14)$$

其中,  $H_{\text{RDB},d}(\cdot)$  为第  $d$  个 RDB 的非线性操作函数。

灰度图像经过所有的 RDB 特征提取后的  $F_D$  表示为

$$F_D = H_{\text{RDB},D}(F_d) \quad (15)$$

针对频谱感知特定的应用范围, 利用 FC 中 Softmax 函数对接收信号进行分类, 得到分类标签结果  $H_0$  或  $H_1$ , 进而完成频谱感知。

本文设置 ResDenNet 的 RDB 内部的卷积核大小为  $1 \times 1$ , 浅层特征提取的卷积核为  $3 \times 3$ , 每层卷积核的个数为 8。

### 3.4 ResDenNet 频谱感知算法

ResDenNet 算法选择  $m$  对训练样本数据  $\{(x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)})\}$ ,  $n$  对测试样本数据  $\{(x^{(m+1)}, y^{(m+1)}), \dots, (x^{(m+n)}, y^{(m+n)})\}$ , 其中,  $x^{(i)}$  为接收信号的矩阵,  $y^{(i)}$  为接收信号的分类标签值。训练方法使用动量随机梯度下降法 (SGDM, stochastic gradient descent with momentum), ResDenNet 算法的输入输出的映射图满足

$$F_D(x_i, \{W\}) = \hat{y}^{(i)} \cong y^{(i)} \quad (16)$$

ResDenNet 训练的损失函数为

$$\text{loss}(W) = - \sum_{k=1}^2 y^{(m)}(k) \log \hat{y}^{(m)}(k) + (1 - y^{(m)}(k)) \log(1 - \hat{y}^{(m)}(k)) \quad (17)$$

ResDenNet 频谱感知算法如算法 1 所示。

**算法 1** ResDenNet 频谱感知算法

**输入** 训练样本  $\{(x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)})\}$ , 采用 SGDM 初始化权值  $W$ , 最大迭代次数 IterMax, 测试样本  $\{(x^{(m+1)}, y^{(m+1)}), \dots, (x^{(m+n)}, y^{(m+n)})\}$

**输出**  $P_d$  和  $P_{fa}$

**步骤 1** (训练阶段) 输入训练样本  $\{(x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)})\}$

**步骤 2** while  $i < \text{IterMax}$  do

$$\begin{cases} F_0 = H(W \times x^{(i)}) \\ F_d = H_{\text{RDB},d}(F_{d-1}) = H_{\text{RDB},d}(H_{\text{RDB},d-1}(\dots H_{\text{RDB},1}(F_0)\dots)) \quad d \geq 1 \\ F_D = H_{\text{RDB},D}(F_d) \end{cases}$$

按照式(16)更新  $\hat{y}^{(m)}$

$$\text{loss}(\mathbf{W}) = -\sum_{k=1}^2 y^{(m)}(k) \log \hat{y}^{(m)}(k) +$$

$$(1 - y^{(m)}(k)) \log(1 - \hat{y}^{(m)}(k))$$

$i = i+1$

end while

**步骤 3** (测试阶段) 将测试样本数据  $\{(x^{(m+1)}, y^{(m+1)}), \dots, (x^{(m+n)}, y^{(m+n)})\}$  输入训练完成的 ResDenNet 模型中, 准确识别授权用户发射信号的样本数量为  $k_{\text{signal}}$ , 准确识别纯噪声的样本数量为  $k_{\text{noise}}$

**步骤 4** 计算  $P_d = \frac{k_{\text{signal}}}{n}$ ,  $P_{\text{fa}} = \frac{n - k_{\text{noise}}}{n}$

## 4 实验结果及分析

### 4.1 测试配置

本节通过 MATLAB 仿真 QPSK 解调过程, 得到  $I$ 、 $Q$  两路信号的  $N$  个采样点数值, 分割成  $M$  行  $n/M$  列的矩阵并进行归一化灰度处理。噪声采用均值为 0、方差为 1 的 WGN (或粉红噪声)。为模拟信道衰落效应, 本节实验使用 MATLAB 仿真瑞利分布信道。训练时参数按高斯分布随机初始化, 损失函数为交叉熵误差函数, 将小批量 (MB, mini-batch) 设置为 128, 使用 SGDM 作为训练方法, 其中, 动量因子设置为 0.9, 学习率设置为 0.01。通过改变 Simulink 的 AWGN 模块参数, 得到不同 SNR 下授权用户发射信号数据。

### 4.2 算法的性能对比

为了验证所提方法的有效性。本节设计 5 个实验: 实验 1 研究网络层数对 ResDenNet、CNN 频谱感知方法性能的影响; 实验 2 考察采样点数对 ResDenNet 频谱感知方法性能的影响; 实验 3 对比 ResDenNet、CNN<sup>[19]</sup>和 SVM<sup>[10]</sup>频谱感知方法的感知效率; 实验 4 对比在 WGN、粉红噪声情况下, ResDenNet、CNN 和 SVM 频谱感知方法的  $P_d$ ; 实验 5 比较 ResDenNet、CNN 和 SVM 频谱感知方法的受试者工作特征 (ROC, receiver operating characteristic) 曲线。

1) 网络层数对 ResDenNet、CNN 频谱感知方法性能的影响

本节实验中, 2 种网络的参数相同、结构不同。ResDenNet 含有捷径连接和密集连接, CNN 无捷径连接和密集连接。为全面考察网络层数对 ResDenNet、CNN 频谱感知方法性能的影响, 实验选择多个 SNR 混合的授权用户发射信号作为训练

样本: 在 SNR 为  $-19 \sim 0$  dB 范围内以 1 dB 为间隔, 每种 SNR 取 50 对信号数据, 组成的 1 000 对信号数据作为有信号的训练样本; 取 1 000 对 WGN 信号作为没有信号的训练样本。测试样本选取方法如下: 每种 SNR 取 5 对信号数据, 组成的 100 对信号数据作为有信号的测试样本; 取 100 对 WGN 信号作为没有信号的测试样本。

ResDenNet、CNN 分类准确率随网络层数  $L$  的变化如图 8 所示。由图 8 可知, 当  $L < 11$  时, ResDenNet 的准确率比 CNN 略高; 当  $L \geq 11$  时, ResDenNet 的准确率明显高于 CNN。如当  $L$  为 5、20、74 时, ResDenNet 的准确率分别比 CNN 高 4%、34%、69%。原因在于 ResDenNet 的密集连接对输入的特征图信息重利用, 提升了 ResDenNet 的特征提取能力, 并且密集连接和捷径连接缓解了梯度消失问题, 有利于提高分类准确率。从图 8 还可以看出, 当  $L = 20$  层时, ResDenNet 的准确率为最大值 94%。可见采用 ResDenNet 实现频谱感知时,  $L$  并不需要太多, 后文 ResDenNet 频谱感知方法取 20 层。

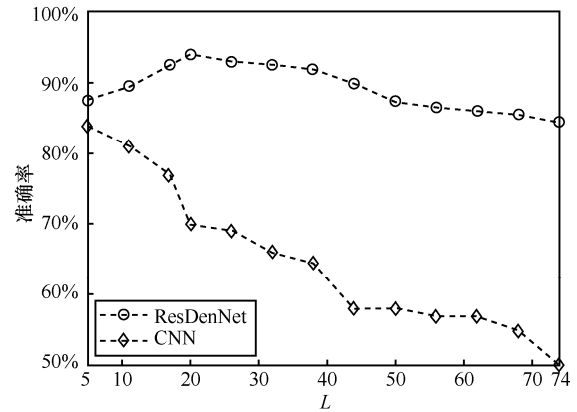


图 8 ResDenNet、CNN 准确率随网络层数的变化

为了进一步说明深层 CNN 频谱感知分类准确率下降是由于梯度消失引起的, 图 9 给出了 20 层、44 层、74 层 ResDenNet、CNN 损失随迭代次数的变化。

由图 9 可知, 3 种网络层数下 ResDenNet 频谱感知模型的损失波动幅度均比 CNN 大; 20 层、44 层、74 层 CNN 频谱感知模型的损失分别稳定在 0.63、0.65、0.70 左右。与 20 层、44 层 CNN 相比, 74 层 CNN 的损失更为平稳。由式(17)可知, 损失函数与  $\hat{y}^{(i)}$  有关, 由式(16)可知, 映射图的输出  $\hat{y}^{(i)}$  与  $\mathbf{W}$  有关。损失函数一直处于平稳状态, 可知卷积层的  $\mathbf{W}$  没有进行更新, 在深层 CNN 中发生了梯度消失, 同样说明, 本文所提方法梯度消失不严重。

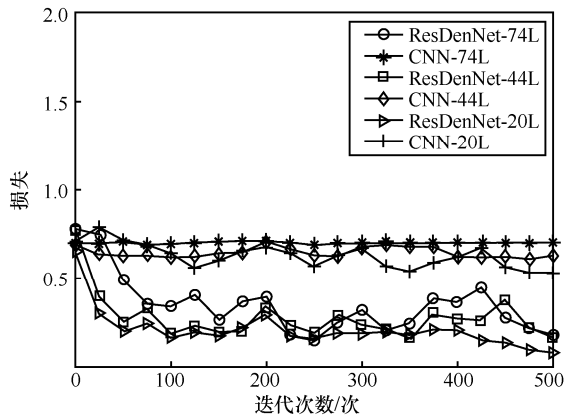


图 9 20 层、44 层、74 层 ResDenNet、CNN 损失随迭代次数的变化

2) 采样点数对 ResDenNet 频谱感知方法性能的影响

在具体频谱感知过程中，可以通过 QPSK 系统获取不同的采样点数，来完成频谱感知工作。不同的采样点数可能影响 ResDenNet 频谱感知方法的性能。不失一般性，以 64、81、100、400、900、1 600 个采样点为例，分析 ResDenNet 的频谱感知分类准确率随采样点数的变化情况，如图 10 所示。




图 10 ResDenNet 准确率随采样点数的变化

由图 10 可知，随着采样点数增大，ResDenNet 频谱感知分类准确率总体呈先上升再下降的趋势。如当 SNR=-19 dB，采样点数为 64、81、100、400、900、1 600 时，频谱感知分类准确率分别为 74%、80%、90%、84%、80%、69%。由此可知，I 路、Q 路的采样点数并不需要太多，下面本文以采样点数为 100 为例，进行实验分析。

3) ResDenNet、CNN 和 SVM 频谱感知方法感知效率的对比

本节实验中，2 种 CNN 分别为 5 层<sup>[19]</sup>（对应 CNN-5L）和 20 层与所提方法具有相同参数的网络

结构（对应 CNN-20L），ResDenNet 与 CNN-20L 不同之处在于有无捷径连接和密集连接，训练样本和测试样本选取方法同 4.2.1 节。

几种算法的  $P_d$ 、 $P_{fa}$ 、训练时间和感知时间如表 1 所示。由表 1 可见，与 CNN-20L 相比，本文方法的  $P_d$  提升 71%， $P_{fa}$  降低 57%，所需训练时间缩短 10%，感知时间降低 12%。这是由于 ResDenNet 中的捷径连接和密集连接提高了收敛速度，缩短了训练时间，同时缓解深层 CNN-20L 由梯度消失带来的  $P_d$  下降的问题。与 CNN-5L 相比，本文所提方法的训练时间增加了 26%，感知时间增加了 95%。原因在于本文方法具有 20 层深层网络，深层网络比浅层网络提取的特征信息更丰富，计算量略有提高。尽管如此，本文方法的  $P_d$  提升了 13%， $P_{fa}$  降低了 68%。与 SVM 相比，本文方法的  $P_d$  提升了 124%， $P_{fa}$  降低了 83%且所需训练时间增加了 113%，感知时间降低了 62%。这是由于 ResDenNet 方法训练参数多于 SVM，因此训练时间长。感知阶段，ResDenNet 算法可对接收信号的灰度图像直接进行频谱感知，而 SVM 算法需重新提取特征参数，所以 ResDenNet 频谱感知方法所需的感知时间较短。考虑到在实际应用中训练过程一般是一次性完成，而检测过程要实时进行。因此，本文所提出的 ResDenNet 在实际应用中是高效可行的频谱感知方法。

表 2 几种算法的  $P_d$ 、 $P_{fa}$ 、训练时间和感知时间

算法	$P_d$	$P_{fa}$	训练时间/s	感知时间/s
ResDenNet	0.94	0.06	32.42	4.06
CNN-5L	0.83	0.19	25.66	2.80
CNN-20L	0.55	0.14	36.11	4.62
SVM	0.42	0.36	15.24	10.72

从计算复杂度方面分析。 $n$  为训练样本数量。SVM 算法的复杂度为  $O(n + n^3)$ <sup>[24]</sup>。CNN 算法的复杂度为  $O(n \sum_{l=1}^L F_l^2 K_l^2 Q_l Q_{l-1})$ <sup>[25]</sup>，其中， $L$ 、 $F_l$ 、 $K_l$  和  $Q_l$  分别为网络总层数、第  $l$  层卷积层输出特征图长度、卷积核长度和输出通道数。ResDenNet 与 CNN 算法计算复杂度的不同之处在于  $l$ 。ResDenNet 算法中的捷径连接和密集连接通过连接任意 2 个卷积层，而 CNN 中的  $l$  要从第一层堆叠到第  $L$  层，因此 ResDenNet 减少了训练参数，降低了计算复杂度。3 种算法的计算复杂度排序为 SVM > CNN > Res DenNet。

4) WGN、粉红噪声条件下本文方法与传统 CNN 和 SVM 频谱感知方法的  $P_d$

本节实验中传统 CNN 频谱感知方法使用了经典的 5 层网络结构, SNR 在  $-19\sim 0$  dB 范围内以 1 dB 为间隔变化, 每种 SNR 下取非授权用户测得的 1 000 对信号数据, 同时取 1 000 对 WGN 噪声数据为训练样本数据, 每种 SNR 下取非授权用户测得的 100 对信号数据, 同时取 100 对 WGN 或粉红噪声数据为测试样本数据。

当测试样本中的噪声为 WGN 时, 图 11 给出了 ResDenNet、CNN 和 SVM 频谱感知方法在 SNR 为  $-19\sim 0$  dB 的  $P_d$ 。由图 11 可见, 当  $SNR < -10$  dB 时, 在  $P_d$  方面 ResDenNet 与其他频谱感知算法相比均表现出优势。例如, 当  $SNR = -19$  dB 时, ResDenNet、CNN、SVM 的  $P_d$  分别为 0.86、0.70、0.60。当  $SNR \geq -10$  dB 时, ResDenNet 的  $P_d$  与 CNN 的  $P_d$  相近, 均比 SVM 高 10%。由此可知, ResDenNet 频谱感知方法优于 CNN、SVM 频谱感知方法。尤其是在低 SNR 的情况下, ResDenNet 频谱感知方法的性能增益更明显。其原因是, 在训练深层网络时, 捷径连接和密集连接起到了重要的作用。ResDenNet 利用密集连接, 使接收信号的特征信息重利用。同时, ResDenNet 的捷径连接解决了深层 CNN 频谱感知方法的梯度消失问题。深层网络的特征提取能力优于浅层网络, 有助于提高频谱感知的  $P_d$ 。从图 11 还可以看出, 在不同的信道环境(Rayleigh 和 AWGN)、不同的调制方式(QPSK 和 BPSK)下, ResDenNet 频谱感知算法的检测性能基本相同, 充分说明了所提 ResDenNet 算法具有较强的稳健性和实用性。

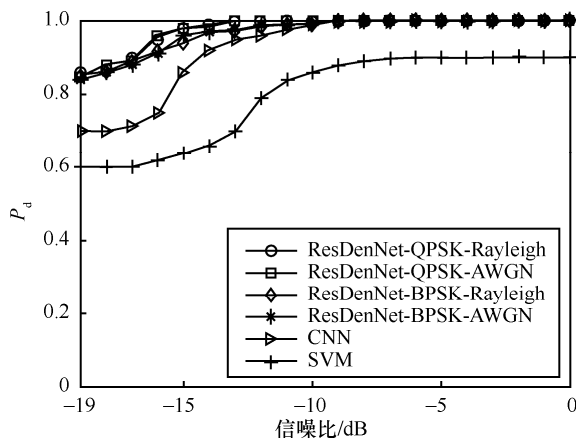


图 11 ResDenNet、CNN 和 SVM 频谱感知方法在不同 SNR、测试样本噪声为 WGN 下的  $P_d$

大多数传统频谱感知方法都是基于噪声是高斯白噪声的假设。然而, 在实际频谱感知过程中, 通信信道会不可避免地受到粉红噪声的影响。所以本文进一步验证了所提方法在粉红噪声频谱感知环境下的泛化能力。为了进一步说明 ResDenNet 方法对不同噪声功率不确定性具有稳健性, 图 12 比较了在不同 SNR、3 种方法不同噪声不确定性 ( $P = (1.0, 1.1, 1.2)$  dB,  $P$  为噪声不确定性因子) 下的  $P_d$ 。

由图 12 可知, 当存在噪声功率不确定性时, 本文方法的频谱感知性能几乎不受影响, 说明了该方法对噪声功率不确定性具有稳健性。当  $SNR < -10$  dB 时在  $P_d$  方面 ResDenNet 与其他频谱感知算法相比均表现出了优势。例如, 当  $SNR = -19$  dB,  $P = 1.0$  dB 时, ResDenNet、CNN、SVM 的  $P_d$  分别为 0.80、0.66、0.40。当  $SNR \geq -10$  dB 时, ResDenNet 的  $P_d$  与 CNN 的  $P_d$  相近, 均比 SVM 高 20%。可见本文方法在训练样本中学习白噪声的特征, 即使测试样本是未经过训练的粉红噪声, 本文方法也能以较高的  $P_d$  识别出授权用户发射信号, 可见本文方法对不同特性噪声下的频谱感知问题具有较强的泛化能力。

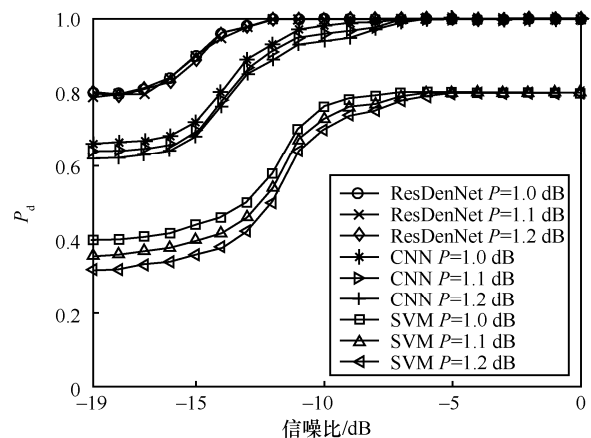


图 12 不同 SNR、3 种方法不同噪声不确定性下的  $P_d$

5) 本文方法与传统 CNN、SVM 频谱感知方法的 ROC 曲线

记录 1 000 次的  $P_{fa}$  与  $P_d$  得到 ResDenNet、CNN 和 SVM 频谱感知方法的 ROC 曲线, 如图 13 所示。传统 CNN 频谱感知方法使用经典的 5 层网络结构, 以  $SNR = -19$  dB 为例, 训练样本取非授权用户测得的 1 000 对信号和 1 000 对 WGN, 测试样本取非授权用户测得的 100 对信号和 100 对 WGN。




图 13 ResDenNet、CNN 和 SVM 频谱感知方法的 ROC 曲线

由图 13 可知, 在  $P_{fa}$  一定时, 本文方法的  $P_d$  高于 CNN、SVM 方法。例如, 在  $P_{fa}$  为 0.1 时, ResDenNet、CNN、SVM 的  $P_d$  分别为 0.96、0.75、0.46。其原因是 ResDenNet 频谱感知方法使用局部残差学习结合了接收信号的浅层和深层的特征, 提高了频谱感知模型的特征提取能力, 改善了卷积层中信息传递, 提高了频谱感知的  $P_d$ 。

## 5 结束语

传统 CNN 频谱感知方法的特征图信息利用率低、不易训练深层网络来提升频谱感知的准确率。本文在传统 CNN 频谱感知方法中加入捷径连接和密集连接, 提出一种基于 ResDenNet 的频谱感知方法。数值实验及理论分析表明, 该方法充分利用特征图信息并且采用深层网络训练频谱感知模型, 可提取更丰富、更深层的频谱信号矩阵图像特征, 有助于提高灰度图像识别和分类的准确率, 进而提升频谱感知性能。与传统 CNN、SVM 算法相比, 本文提出的 ResDenNet 频谱感知方法在  $P_{fa}$  一致的情况下, 有着较高的  $P_d$ , 当  $P_d$  一致时本文方法的  $P_{fa}$  较低, 且对不同特性噪声下的频谱感知问题具有较强的泛化能力。下一步拟进一步研究残差密集网络在多用户协作式频谱感知方法中的应用。

## 参考文献:

[1] DIGHAM F F, ALOUINI M S, SIMON M K. On the energy detection of unknown signals over fading channels[J]. IEEE Transactions on Communications, 2007, 55(1): 21-24.  
 [2] WU J Y, WANG C H, WANG T Y. Performance analysis of energy detection based spectrum sensing with unknown primary signal arrival time[J]. IEEE Transactions on Communications, 2011, 59(7): 199-206.

[3] OH H, NAM H. Energy detection scheme in the presence of burst signals[J]. IEEE Signal Processing Letters, 2019, 26(4): 582-586.  
 [4] YANG M C, LI Y, LIU X F, et al. Cyclostationary feature detection based spectrum sensing algorithm under complicated electromagnetic environment in cognitive radio networks[J]. China Communications, 2015, 12(9): 35-44.  
 [5] SHEN J C, ALSUSA E. Joint cycle frequencies and lags utilization in cyclostationary feature spectrum sensing[J]. IEEE Transactions on Signal Processing, 2013, 61(21): 5337-5346.  
 [6] ZHANG X Z, GAO F F, CHAI R, et al. Matched filter based spectrum sensing when primary user has multiple power levels[J]. China Communications, 2015, 12(2): 21-31.  
 [7] LIU C, WANG J, LIU X M, et al. Maximum eigenvalue-based goodness-of-fit detection for spectrum sensing in cognitive radio[J]. IEEE Transactions on Vehicular Technology, 2019, 68(8): 7747-7760.  
 [8] AWE O P, DELIGIANNIS A, LAMBOTHARAN S. Spatio-temporal spectrum sensing in cognitive radio networks using beamformer-aided SVM algorithms[J]. IEEE Access, 2018, 6: 25377-25388.  
 [9] BAO J R, NIE J Y, LIU C, et al. Improved blind spectrum sensing by covariance matrix Cholesky decomposition and RBF-SVM decision classification at low SNRs[J]. IEEE Access, 2019, 7: 97117-97129.  
 [10] 陈思吉, 王欣, 申滨. 一种基于支持向量机的认知无线电频谱感知方案[J]. 重庆邮电大学学报(自然科学版), 2019, 31(3): 313-322.  
 CHEN S J, WANG X, SHEN B. A support vector machine based spectrum sensing for cognitive radios[J]. Journal of Chongqing University of Posts and Telecommunications(Natural Science Edition), 2019, 31(3): 313-322.  
 [11] TANG Y J, ZHANG Q Y, LIN W. Artificial neural network based spectrum sensing method for cognitive radio[C]//Proceedings of 2010 6th International Conference on Wireless Communications Networking and Mobile Computing (WiCOM). Piscataway: IEEE Press, 2010: 1-4.  
 [12] VYAS M R, PATEL D K, LOPEZ-BENITEZ M. Artificial neural network based hybrid spectrum sensing scheme for cognitive radio[C]//Proceedings of 2017 IEEE 28th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC). Piscataway: IEEE Press, 2017: 1-7.  
 [13] 高红民, 曹雪莹, 杨耀, 等. 基于 CNN 的双边融合网络在高光谱图像分类中的应用[J]. 通信学报, 2020, 41(11): 132-140.  
 GAO H M, CAO X Y, YANG Y, et al. Application of bilateral fusion model based on CNN in hyperspectral image classification[J]. Journal on Communications, 2020, 41(11): 132-140.  
 [14] YU C Y, HAN R, SONG M P, et al. A simplified 2D-3D CNN architecture for hyperspectral image classification based on spatial-spectral fusion[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 2485-2501.  
 [15] MAFFEI A, HAUT J M, PAOLETTI M E, et al. A single model CNN for hyperspectral image denoising[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(4): 2516-2529.  
 [16] CHEN Y S, ZHU K Q, ZHU L, et al. Automatic design of convolutional neural network for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(9):

7048-7066.

- [17] LIU C, WANG J, LIU X M, et al. Deep CM-CNN for spectrum sensing in cognitive radio[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(10): 2306-2321.
- [18] LEE W, KIM M, CHO D H. Deep cooperative sensing: cooperative spectrum sensing based on convolutional neural networks[J]. IEEE Transactions on Vehicular Technology, 2019, 68(3): 3005-3009.
- [19] 张孟伯, 王伦文, 冯彦卿. 基于卷积神经网络的 OFDM 频谱感知方法[J]. 系统工程与电子技术, 2019, 41(1): 178-186.
- ZHANG M B, WANG L W, FENG Y Q. OFDM spectrum sensing method based on convolutional neural networks[J]. Systems Engineering and Electronics, 2019, 41(1): 178-186.
- [20] MARSHALL J A. Neural networks for pattern recognition[J]. Neural Networks, 1995, 8(3): 493-494.
- [21] JAMES D A, VENABLES W N, RIPLEY B D. Modern applied statistics with S-PLUS[J]. Technometrics, 1996, 38(1): 77.
- [22] PHATAK D S, KOREN I. Connectivity and performance tradeoffs in the cascade correlation learning architecture[J]. IEEE Transactions on Neural Networks, 1994, 5(6): 930-935.
- [23] WILAMOWSKI B M, YU H. Neural network learning without back-propagation[J]. IEEE Transactions on Neural Networks, 2010, 21(11): 1793-1803.
- [24] 陈丽, 陈静, 高新涛, 等. 基于支持向量机与反 K 近邻的分类算法研究[J]. 计算机工程与应用, 2010, 46(24): 135-137, 188.
- CHEN L, CHEN J, GAO X T, et al. Classification algorithm research based on support vector machine and reverse K-nearest neighbor[J]. Computer Engineering and Applications, 2010, 46(24): 135-137, 188.
- [25] 孙月驰, 李冠. 基于卷积神经网络嵌套模型的人群异常行为检测[J]. 计算机应用与软件, 2019, 36(3): 196-201, 276.
- SUN Y C, LI G. Abnormal behavior detection of crowds based on nested model of convolutional neural network[J]. Computer Applications and Software, 2019, 36(3): 196-201, 276.

### [作者简介]



盖建新 (1980- ), 男, 辽宁朝阳人, 博士, 哈尔滨理工大学副教授, 主要研究方向为频谱感知、机器学习、亚奈奎斯特采样理论、压缩感知等。



薛宪峰 (1996- ), 男, 山东菏泽人, 哈尔滨理工大学硕士生, 主要研究方向为深度学习。



南瑞祥 (1996- ), 男, 山东济宁人, 哈尔滨理工大学硕士生, 主要研究方向为通信信号处理。



吴静媛 (1996- ), 女, 黑龙江绥化人, 哈尔滨理工大学硕士生, 主要研究方向为压缩感知。